PATENT ABSTRACTS OF JAPAN

(11)Publication number:

09-069101

(43) Date of publication of application: 11.03.1997

(51)Int.Cl.

G06F 17/27

(21)Application number: 07-223017

(71)Applicant: HITACHI LTD

(22)Date of filing:

31.08.1995

(72)Inventor: SATO YOSHIFUMI

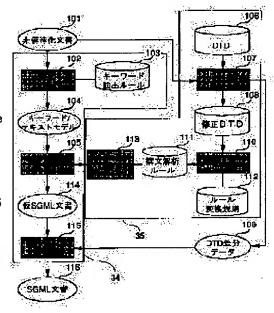
HINO MASATOSHI

(54) METHOD AND DEVICE FOR GENERATING STRUCTURED DOCUMENT

(57)Abstract:

PROBLEM TO BE SOLVED: To easily prepare a structured document matched with the logical structure of an individual document by executing conversion from a non- structured document to a structured document by the use of a rule directly prepared from previously set logical structure definition.

SOLUTION: A keyword extracting part 102 extracts a keyword expressing logical structure from a non-structured document 101 by the use of a keyword extraction rule 103 and generates a keyword/text model 104 expressing the document 101 by the keyword and two kinds of character string elements. A syntax analysis part 105 generated by a syntax analysis part automatic generation procedure 113 by referring to a syntax analysis rule 110 prepared by correcting/converting a DTD 106 executes syntax analysis for the model 104 and generates a temporary SGML document 114. An SGML document correcting part 115 corrects the document 114 by referring to DTD difference information 109 generated at the time of preparing the rule 110 and generates an SGML document 116 to be a final output.



LEGAL STATUS

[Date of request for examination]

04.08.2000

[Date of sending the examiner's decision of rejection]

07.09.2004

[Kind of final disposal of application other than the examiner's decision of rejection or application

converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

(19)日本国特許庁 (JP) (12) 公開特許公報 (A)

(11)特許出願公開番号

特開平9-69101

(43) 公開日 平成 9年(1997) 3月11日

(51) Int.Cl.⁶

G06F 17/27

識別記号

庁内整理番号

FΙ

技術表示箇所

G06F 15/20

550F

550A

審査請求 未請求 請求項の数9 OL (全 15 頁)

(21)出願番号

(22)出願日

特願平7-223017

平成7年(1995)8月31日

(71)出願人 000005108

株式会社日立製作所

東京都千代田区神田駿河台四丁目6番地

(72)発明者 里 佳史

神奈川県川崎市麻生区王禅寺1099番地 株

式会社日立製作所システム開発研究所内

(72)発明者 樋野匡利

神奈川県川崎市麻生区王禅寺1099番地 株

式会社日立製作所システム開発研究所内

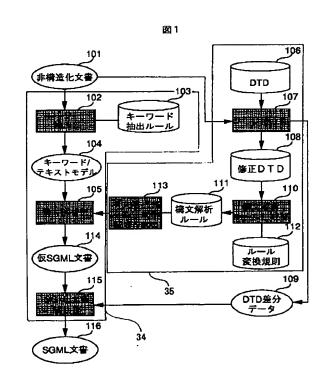
(74)代理人 弁理士 小川 勝男

(54) 【発明の名称】 構造化文書生成方法および装置

(57)【要約】

【目的】非構造化文書から構造化文書への変換を、予め 設定された論理構造定義から直接的に作成したルールを 用いて行い、個々の文書の論理構造に即した構造化文書 の作成を容易にする。

【構成】キーワード抽出部102は、キーワード抽出ルー ル103を用いて非構造化文書101から論理構造を表すキー ワードを抽出し、非構造化文書101をキーワードとそれ 以外の文字列の二種の要素で表現したキーワード/テキ ストモデル104を生成する。DTD106を修正・変換して作 成した構文解析ルール110を参照して構文解析部自動生 成手続き113が生成した構文解析部105は、キーワード/ テキストモデル104に対する構文解析を行い、仮SGML文 書114を生成する。SGML文書修正部115は、構文解析ルー ル作成時に生成されたDTD差分情報109を参照して仮SGML 文書113を修正し、最終出力であるSGML文書116を生成す る。



1

【特許請求の範囲】

【請求項1】少なくとも入力表示装置、制御装置、および記憶装置を含み、文書の論理構造を規定する論理構造 定義に基づき、構造が明示されていない文書である非構造化文書を前記入力表示装置により入力し、入力された 非構造化文書を構造が明示されている文書である構造化 文書に変換し、前記構造化文書を出力する構造化文書生 成装置において、

予め与えられた第1の論理構造定義を、入力された非構造化文書の文書構造に適合させて修正して第2の論理構 10 造定義を作成し、

作成された第2の論理構造定義を構成する記号および該記号の配列順序と1対1に対応すべく前記第2の論理構造定義を変形して前記第2の論理構造定義が規定する論理構造に適合した構文解析を行うための構文解析ルールを前記制御装置にて生成し、

生成された構文解析ルールに基づき、入力された前記非 構造化文書から第1の構造化文書を生成し、

生成された第1の構造化文書を、前記第1の論理構造定義と前記第2の論理構造定義との差分データに基づき、前記第1の論理構造定義に従う形式に変換して第2の構造化文書を生成することを特徴とする構造化文書生成方法。

【請求項2】請求項1に記載の構造化文書生成方法において、

前記第1および第2の論理構造定義は、入力されるべき 文書を構成する文字列間の相互関係を規定すべく配置さ れた記号列であることを特徴とする構造化文書生成方 法

【請求項3】請求項1または2に記載の構造化文書生成 30 方法において、

前記第1および第2の論理構造定義は、少なくとも、対応する文書中の各文字列の概念的な上下関係を表す論理構造を、前記各文字列の概念に当てた名称を所定の方法で配列して表現した記号列を含むことを特徴とする構造化文書生成方法。

【請求項4】請求項1または2に記載の構造化文書生成 方法において、

前記非構造化文書から、文書中の文字列に係る所定のルールに基づきキーワードを抽出して、少なくともキーワ 40 ードとして抽出された文字列とそれ以外の文字列とを含むキーワード/テキストモデルを生成し、

前記構文解析ルールを用いて前記キーワード/テキスト モデルを前記第1の構造化文書に変換することを特徴と する構造化文書生成方法。

【請求項5】請求項4に記載の構造化文書生成方法において.

前記キーワードは、文字列の書式条件とキーワード名称 とを対応づけたキーワード抽出ルールを参照して、前記 非構造化文書中の文字列をいずれのキーワードであるか 50

認識することによって抽出することを特徴とする構造化 文書生成方法。

【請求項6】請求項5に記載の構造化文書生成方法において

前記キーワード抽出ルールは、前記非構造化文書の出力 書式定義が与えられている場合には、前記出力書式定義 を所定のルールに基づき変換して作成することを特徴と する構造化文書作成方法。

【請求項7】請求項4に記載の構造化文書生成方法において、

同一の文字列領域から同一の文字列が異なる複数のキーワードとして抽出される場合には、前記制御装置が構文解析の成否を基準に前記複数のキーワードの中から適切なキーワードを選択することを特徴とする構造化文書生成方法。

【請求項8】請求項1または2に記載の構造化文書生成 方法において、

前記構文解析ルールは、与えられたルール変換規則に基づき前記第2の論理構造定義を変換して生成された中間ルールに、構文解析時に解析された構文を明示するための手続きを埋め込んで生成することを特徴とする構造化文書生成方法。

【請求項9】少なくとも入力表示装置、制御装置、および記憶装置を含み、構造が明示されていない文書である 非構造化文書を構造が明示されている文書である構造化 文書に変換する構造化文書生成装置において、

前記非構造化文書のレイアウト情報と文字列情報とから、前記非構造化文書の論理構造の構成要素を表す文字列をキーワードとして抽出するキーワード抽出手段と、与えられた第1の論理構造定義を修正して作成した第2の論理構造定義から、前記非構造化文書を前記第2の論理構造定義に適合する構造化文書に変換するルールを生成するルール生成手段と、

前記キーワード抽出部で抽出されたキーワードと前記ルール生成部で生成されたルールとを用いて前記構造化文書を生成する構造化文書生成部とを有することを特徴とする構造化文書生成装置。

【発明の詳細な説明】

[0001]

【産業上の利用分野】本発明は法規文書等一定の文書構造を有する文書の管理に関し、特に、文字認識やワードプロセッサ等の手段によって入力された、文書の構造を明示的に表す情報を含まない文書(以下「非構造化文書」と呼ぶ)を、文書の構造を明示的に表す情報を含む文書(以下「構造化文書」と呼ぶ)に変換する方法および装置に関する。

[0002]

【従来の技術】構造化文書の形式の一つに、論理構造を明示的に表す情報をテキスト中に埋め込む方法がある。 一般にユーザが作成した構造化文書(以下「文書インス

2

タンス」と呼ぶ)は、文書の論理構造を規定する論理構造定義を記述したファイルを指定する部分と、文書の内容を表す内容テキスト部とを含むことが多い。論理構造定義には、その文書の論理構造と、その構成要素を表すマーク(以下「タグ」と呼ぶ)とが定義される。このように、文書の論理構造化を行なう場合には、対象とする文書を活用するための論理構造定義が設定されている場合が多い。また、内容テキスト部には、論理構造定義内で定義されたタグを、そのタグに対応する論理構造の内容となる文字列が一意に定まるように挿入し、文書の論理10構造を明示的に表現する。

【0003】このようにして構造化された文書インスタンスを出力する際には、論理構造の各構成要素(以下「論理構造要素」と呼ぶ)をどのような書式で出力するかを規定する出力書式定義を記述したファイルを参照し、出力すべきイメージを生成する。この方法によると、文書インスタンスと出力書式定義とが独立しているために、出力に用いる個々の装置やシステムに関わらず文書インスタンスを交換することができる。

【0004】また、こうした構造化文書における文字列 20 の内容は、例えば「〈著者名〉」や「〈タイトル〉」というような、論理構造要素と一対一で対応するタグの挿入によって明示的に表現される。このため、構造化文書に対応した全文検索システム等のツールと組み合わせることにより、文書インスタンスの集合をそのままデータベースとして利用することができ、文書内容の追加・変更も容易となる。さらに、このデータベースの一部が障害等により喪失した場合、元の論理構造定義とデータベースである文書インスタンスとを照合することにより、データベース中に喪失部分があることを発見できる。 30

【0005】こうした利点から、大量の文書を蓄積・利用する文書処理システムにおける文書管理形式として、構造化文書形式の採用が進んでいる。これに伴い、既存の紙面文書やワープロ入力文書などの非構造化文書を構造化文書へと変換する手法がいくつか提案されている。

【0006】特開昭62-249270や「文書画像のODA論理構造化文書への変換方式(電子情報通信学会論文誌 D-II V ol. J76-DII No. 11 pp. 2274-2284)」においては、対象とする文書型の分野を限定し、その分野において共通性のある論理構造(以下「共通論理構造」と呼ぶ)及び論理構 40 造認識ルールを用いて構造化文書の生成を行なう方法が提案されている。この方法では、まず「技術文書」「ビジネス文書」など対象とする文書の分野毎に、その分野で共通して用いることのできる論理構造を設定し、その論理構造に沿った論理構造認識を行なうためのルールを人手によって作成する。そして、そのルールを用いて非構造化文書を共通論理構造に即した文書インスタンスに変換する。さらに、共通論理構造において表現できない個々の文書の論理構造(以下「個別論理構造」と呼ぶ)固有の構成要素が存在する場合には、共通論理構造に沿っ 50

た文書インスタンスを個別論理構造に沿った形に変換し 直す。

[0007]

【発明が解決しようとする課題】しかしながら、従来の 方法では、論理構造認識を行なうための論理構造及びル ールは対象になる文書の分野に依存するため、分野の異 なる文書を扱う際には、その分野に対応したルールを新 たに人手で生成する必要があり、その作業には多大な労 力を要するという問題があった。

【0008】また、従来の方法では、ある特定の分野における複数種類の文書に対して共通性の高いと思われる単一のルールを用いるため、そのルールは各々の文書に必ずしも適合するものではなく、個別論理構造固有の構成要素は直接認識することができなかった。そのために、論理構造認識後に、生成された文書インスタンスを個別論理構造に即した形式に変換し直す必要があった。具体的には、生成された文書インスタンスに含まれるタグの追加・変更・削除を行なうことになるが、一般にこの作業には多くの手間がかかり、結果として多大な労力を要するという問題があった。

【0009】本発明は上記問題点に鑑み、ある特定の分野の複数の異なる種類の文書に渡って適切な論理構造認識を行なう方法を提供することを目的とする。また、個別論理構造固有の構成要素を直接認識してその個別論理構造に即した形式の文書インスタンスを直接生成する方法を提供することを目的とする。

[0010]

【課題を解決するための手段】上記目的を達成するた め、本発明は、少なくとも入力表示装置、制御装置、お よび記憶装置を含み、文書の論理構造を規定する論理構 造定義に基づき、構造が明示されていない文書である非 構造化文書を入力表示装置により入力し、入力された非 構造化文書を構造が明示されている文書である構造化文 書に変換し、構造化文書を出力する構造化文書生成装置 において、予め与えられた第1の論理構造定義を、入力 された非構造化文書の文書構造に適合させて修正して第 2の論理構造定義を作成し、作成された第2の論理構造 定義を構成する記号および該記号の配列順序と1対1に 対応すべく第2の論理構造定義を変形して第2の論理構 造定義が規定する論理構造に適合した構文解析を行うた めの構文解析ルールを前記制御装置にて生成し、生成さ れた構文解析ルールに基づき、入力された非構造化文書 から第1の構造化文書を生成し、生成された第1の構造 化文書を、第1の論理構造定義と第2の論理構造定義と の差分データに基づき、第1の論理構造定義に従う形式 に変換して第2の構造化文書を生成することを特徴とす る構造化文書生成方法をその構成とする。

【0011】上記の構成において、非構造化文書から構造化文書への変換は、例えば、抽出したキーワードを手がかりにした構文解析によって論理構造認識を行なう構

文解析部を用いて行うことができる。構文解析部は、与 えられた論理構造定義を構文解析ルール生成部によって 構文解析ルールへと変換し、この構文解析ルールに構文 解析部自動生成手続きを施すことによって生成される。

【0012】ここで、構文解析部自動生成手続きとは、「AはB, C, …というパターンから構成される」というようなルールの集合を入力として、それらのルールに従った構文解析を実行するプログラムを出力するものであり、各ルールが成立した際に実行される特定の処理をルール内に記述することが可能である。このような構文解析部自動生成手続きとしては、例えば、UNIXに標準的に添付されるyaccが挙げられる。

【0013】また、上記の構成において、特に同一の文字列領域の同一文字列が複数の異なるキーワードとして抽出される場合には、制御装置内の構文解析部が構文解析の成否を基準に当該複数種類のキーワードから適切な1つを選択する。

【0014】構造化文書の具体的生成方法は以下の通りである。まず、キーワード抽出部が非構造化文書からキーワードを抽出し、対象とする文書をキーワードとそれ 20以外の文字列とを要素とする集合として抽象化したキーワード/テキストモデルを生成する。

【0015】構文解析部は、キーワードテキスト/モデルに対して構文解析を行ない、構造化文書を生成するが、この構文解析部は以下の手順によって作成する。最初に、与えられた論理構造定義を非構造化文書が持つ論理構造に合わせて修正し、その差分情報を保持しておく。次に、構文解析ルール生成部が、修正後の論理構造定義を構文解析ルールへと変換する。このとき、各ルールが成立した際、すなわち各論理構造要素が検出された。際に、検出された論理構造要素についての情報をキーワード/テキストモデルにおける該当部分に記録する処理プログラムを、構文解析ルールに埋め込んでおく。そして、構文解析部自動生成手続きが、構文解析ルールに記述された構文解析処理を実現する構文解析部を生成する。

【0016】以上の手続きによって生成された構文解析部は、キーワード抽出部の作成したキーワード/テキストモデルに対して構文解析を行ない、キーワード/テキストモデルに記録された構文解析結果を基に、修正後の論理構造定義に沿った仮構造化文書を生成する。構造化文書修正部は、論理構造定義の修正時に作成された論理構造の差分情報を参照して、修正前の論理構造定義に沿った構造化文書を出力する。

[0017]

【作用】上記の構成によれば、論理構造とそれを認識するためのルールを、個々の文書に設定された論理構造定義から変換して作成するため、論理構造認識を行うための論理構造の設計およびルール作成に要する労力を軽減できる。また、個々の文書の論理構造定義を基に動的に 50

作成した構文解析ルールを用いるため、共通論理構造を 介することなく個別論理構造に即した構造化文書を直接 生成することができ、構造化文書を共通論理構造に即し た形から個別論理構造に即した形へと変換し直す必要が ない。

[0018]

【実施例】以下、図面を参照して本発明の一実施例を説 明する。本実施例においては、構造化文書生成部が構文 解析によって論理構造認識を行なうものとする。構造化 文書形式としてSGML形式を採用し、文書の論理構造定義 に相当する概念はSGMLの文書型定義であるDTD(Document Type Definition)であるとする。SGMLおよびDTDの処理 内容や記述規則はISO(国際標準化機構)の標準規約であ るISO 8879において規定されており、その詳細は文献 「SGML入門」(MARTIN BRYAN著、アスキー出版局)に解説 されている。また、本実施例においては、構文解析部自 動生成手続きとして、UNIXに標準添付されているyaccを 用いる。さらに、yaccが入力とする各ルールに対して、 各々が成立した時点で実行される処理を付加する際の記 述言語として、C言語を用いる。yaccの処理の詳細につ いては文献「yaccとlexの使い方」(斉藤孝著、HBJ出版 局)に、C言語については文献「プログラミング言語C」 (B. W. カーニハン&D. M. リッチー著、共立出版) にそれぞ れ解説されている。

【0019】まず、本実施例のシステムの概要を説明す る。図19は本実施例に係る構造化文書生成システムの ハードウエア構成図である。入力表示装置1は、操作者 からの入力を受け付け、また、入力された非構造化文書 や生成された構造化文書などを出力する装置であり、デ ィスプレイ、キーボード、マウス等から構成される。外 部記憶装置2は、構造化文書生成に係る諸データを格納 する装置であり、ハードディスク装置等により実現さ れ、非構造化文書格納部21、構造化文書生成ルール格納 部22、および構造化文書格納部23を有する。制御装置3 は、当該システムを構成する各装置の制御および構造化 文書生成に係る情報処理等を行う装置であり、制御部3 1、内部メモリ32、および構造化文書生成部33を有す る。制御部31は、非構造化文書格納部21および構造化文 書生成ルール格納部22に格納されたデータを読み出して 内部メモリ32上に展開し、このデータを用いて内部メモ リ32上で構造化文書生成部33の有する手続、すなわち構 文解析部生成手続き34および構造化文書生成手続き35を 実行し、その結果生成される構造化文書を構造化文書格 納部23に格納する。構文解析部生成手続き34は、構造化 文書生成手続き35の一部である構文解析部を生成する手 続きである。構造化文書生成手続き35は、構造化文書生 成ルール格納部22に格納された論理構造定義、キーワー ド抽出ルール、ルール変換規則等を用いて、非構造化文 書格納部21に格納された非構造化文書を構造化文書に変 換する手続きである。構文解析部生成手続き34および構 造化文書生成手続き35は公知のプログラミング言語等で 記述できる。

【0020】次に、本実施例の処理概要を説明する。図1は、本実施例に係る構造化文書生成システムにおける構造化文書生成処理の流れを示すブロック図である。非構造化文書101は、ワードプロセッサや文字認識装置等によって作成される一次元的な文字列として電子化された文書情報であり、入力表示装置1によりシステムに入力される。キーワード抽出部102は、まず、キーワード抽出ルール103に従って非構造化文書からキーワードを抽出する。キーワードとは、非構造化文書101の論理構造を表現する文字列である。次に、非構造化文書101をキーワードとそれ以外の文字列とに分解し、これらを要素とする集合として抽象化したキーワード/テキストモデル104を生成する。構文解析部105は、構文解析ルール生成部110が作成した構文解析ルール111に記述された構文解析を実現し、論理構造認識を行なうものである。

【0021】構文解析部105の生成方法の概要は以下の通りである。まず、DTD修正部107において、DTD106を非構造化文書101の記述様式に沿うように修正して修正DTD 20 108を作成し、その差分情報をDTD差分データ109として保持しておく。DTD106は、予め用意された標準的な論理構造定義であり、必ずしも入力された非構造化文書101に適合しているとは限らない。この修正は、非構造化文書101とDTD106とをシステム操作者が見比べた結果に基づいて行なう。構文解析ルール生成部110は、ルール変換規則112を参照して修正DTD108から構文解析ルール111を作成する。そして、本実施例における構文解析部自動生成手続きであるyacc113が、構文解析ルール111から、構文解析ルール111に記述された構文解析処理を実現す 30 る構文解析部105を生成する。

【0022】構文解析部105は、キーワード/テキストモデルに対する構文解析を行ない、論理構造を表すタグを付加して仮SGML文書114を生成する。これは、修正DTD 108に沿った形で生成された文書インスタンスであるため、SGML文書修正部115が、DTD差分データ109を参照して仮SGML文書114を修正することにより、DTD106に沿ったSGML文書116を生成する。

【0023】次に、本実施例における各処理について詳細に説明する。図2は図1における非構造化文書101の例 40を示す。これは、法規を例に紙面文書に対して文字認識を行なった結果であり、論理構造を示す明示的な表記は存在しないが、文書の各構成要素はスペース等を用いて読み易いようにレイアウトされている。このようなテキスト形式の電子化文書を文書処理システムで活用するために、論理構造定義(DTD)が設定されている。図2の非構造化文書に対応するDTDの例を図3に示す。冒頭の301は、この論理構造定義が「条例」という名称であることを示す。302は、論理構造要素「条例」が、「公布」「例規番号」「題名」「本則」「附則」といった論理構 50

造要素の並びによって構成されることを示す。「附則」にアスタリスク(***)が付いているのは、「附則」は任意個存在可能であることを意味する。303は、論理構造要素「公布」が「公布文」「公布年月日」「公布者」の並びによって構成されることを示し、307は「公布者」が「職名」と「氏名」から構成されることを示す。また、(#PCDATA)を構成要素とする304、305、307~310は、それぞれ「公布文」「公布年月日」「職名」「氏名」「例規番号」「題名」といった論理構造要素が、その内容を表す文字列を保持することを意味する。301から310までの論理構造をツリー状に表現したものを図4に示す。

【0024】本システムは、図2に示すような非構造化 文書に対し、図3に示すようなDTDを直接的に利用した論 理構造認識を行うことにより、そのDTDに従った構造化 文書を生成する。

【0025】図1のキーワード抽出部102は、キーワード 抽出ルール103を参照して非構造化文書101からキーワー ドを抽出し、キーワード/テキストモデル104を生成す る。キーワード抽出ルール103の例を図5に示す。このル ールは、キーワードとして抽出すべき論理構造要素名 と、それを抽出するためのレイアウト情報及び文字列情 報を記述した書式条件との組合せの集合である。図5に おいては、各行の先頭の項目がキーワードの名称であ り、二番目以降の項目が書式条件である。図5における 書式条件の記述要素の説明を図6に示す。これによれ ば、例えば図5における501は、キーワード「冒頭題名」 の書式条件が、「行頭からスペース3文字の位置に文字 『〇』が存在し、それに任意長の文字列が続き、最後に 文字列『条例』または文字列『規則』で行が終る。」と いう条件であることを意味する。また、502について は、キーワード「公布年月日」の書式条件が、「行頭か ら任意個のスペースを置いて文字列『大正』または文字 列『昭和』が存在し、その後は順に整数→『年』→整数 →『月』→整数→『日』と続き、行が終る」という条件 であることを意味する。

【0026】図1のキーワード抽出部102は、電子化文書の中にキーワード抽出ルールの書式条件に適合する文字列が存在するか否かを判定し、適合する場合にはその文字列をキーワードとして抽出する(キーワードの抽出例を図7に示す)。そして、対象文書をキーワードとそれ以外の文字列の集合として抽象化したキーワード/テキストモデル104を生成する。具体的には、キーワード間にキーワードに該当しない文字列が挟み込まれる場合、それをキーワード以外の文字列である「テキスト」とみなし、例えば図8に示すようなキーワード/テキストモデルを構成する。図8のキーワード/テキストモデルは、キーワード「冒頭題名」から始まり、その後キーワード「公布年月日」→キーワード「例規番号」→キーワード「公布文」→キーワード「題名」→キーワード「条番

号」と続く。キーワード「条番号」と次のキーワード 「号番号」との間にキーワードでない文字列が挟まれる ため、その部分が「テキスト」とみなされる。

【0027】ところで、文書中の同一の領域の同一文字 列が複数種類のキーワードとして抽出される場合があ る。例えば、図7のキーワード抽出例において、一行目 および二行目の文字列「〇△△県水防信号規則」はそれ ぞれ「冒頭題名」および「題名」をキーワード名とする キーワードとして抽出されたものである。このような場 合には、その領域からそれぞれのキーワードが抽出され たと仮定し、その仮定に対応したキーワード/テキスト モデルを複数生成する。図8は、領域の競合するキーワ ード名「冒頭題名」および「題名」の中から「冒頭題 名」を選択して生成したキーワード/テキストモデルの 例である。この複数のキーワード/テキストモデルにつ いては、後に説明する構文解析部105において構文解析 が行われ、構文解析に失敗したものは不適切なキーワー ド/テキストモデルとみなされる。成功するものが複数 存在する場合には、抽出されたキーワード数等の基準に よって最適なものを選択し、最終的には最適なキーワー ド/テキストモデルに対応するSGML文書が一つだけ生成 される。

【0028】図1の構文解析部105は、キーワード/テキストモデル104に対して、構文解析ルール111に従う構文解析処理を行なう。まず、構文解析ルール生成部107がDTD106を変換して構文解析ルール111を作成する過程を、図9を用いて説明する。

【0029】まず、DTD修正部107において、対象とする 非構造化文書について設定されているDTD106の記述内容 を、認識対象文書の記述様式に対応させるべく修正した 修正DTD108を人手で作成し、その差分をDTD差分データ1 09として保持しておく。このような修正が必要になるの は、非構造化文書101の記述項目及びその記述順と、文 書システムで利用する際に用いるDTD106における記述項 目及びその記述順との間に矛盾が存在しうるためであ る。例えば、図3は、図2に示した非構造化文書101を活 用するために用意されたDTD106である。しかし、図2の 1行目の「○△△県水防信号規則」という冒頭の題名に 対応する論理構造要素は、図3のDTD106の中には用意さ れていない。また、図3のDTD106においては、「公布文 →公布年月日→例規番号→題名」という順に論理構造要 素が並ぶことになっているのに対して、認識対象である 図2の非構造化文書では、「公布年月日→例規番号→公 布文→題名」という順番で各要素が並んでいる。

【0030】このような矛盾に対処するため、まず人手によって図10に示すような修正DTD108を作成する。網掛けで示した部分が修正を加えた部分である。この時、修正を加えた部分を明示的に表現するように、その部分が論理構造要素<CHANGE>で包含されるようにする。また、元のDTD106において修正された部分を、図11に示すよう 50

なDTD差分データ109として保持しておく。ここでも、修正された部分が論理構造〈CHANGE〉に包含されるようにする。

10

【0031】ただし、非構造化文書101に想定される論理構造とDTD106との間に矛盾が存在しない場合には、修正DTD108やDTD差分データ109を作成する必要はない。

【0032】必要に応じてDTD106に修正が加えられると、構文解析ルール生成部110は、図12に示すルール変換規則112に従ってルール変換906を実行し、修正DTD108に記述された論理構造に関する情報を中間yaccルール908へと変換する。中間yaccルールにおける各ルールは、

「A:BC;」というようにコロン": "によって区切られた左辺と右辺から成り、右辺に記述された要素のパターンが存在する場合にルールが成立し、左辺の要素が構成される。例えば、「A:BC;」というルールの場合、「BC」というパターンが存在する時、要素Aが構成されることになる。

【0033】図10に示した修正DTD108を中間yaccルール908に変換した例を図13に示す。例えば、図10における1001のルールを変換すると、図13の1301~1303に示したyaccルールに変換される。ここでは、1001の「目次?」と「附則*」が、図12における下から二つのルールによって、1301ではそれぞれ「opt0」「rep0」に置き換えられる。そして、「opt0」と「rep0」の定義がそれぞれ1302、1303に記述されている。

【0034】ところで、このような中間yaccルールを用 いると、yaccの生成する構文解析部は構文解析の成否の みを出力し、キーワード/テキストモデルと論理構造要 素との対応関係を出力しない。しかし、構文解析の結果 を利用して構造化文書を生成するためには、各論理構造 要素の認識に成功した際、すなわち中間yaccルールにお ける各ルールが成立する時、対応するキーワード/テキ ストモデルに対して該当する論理構造要素に関する情報 を付加する必要がある。そのために、構文解析ルール生 成部110は中間yaccルール908に対して、キーワード/テ キストモデルに情報付加処理を行なうC言語のプログラ ムの埋め込み909を実行し、構文解析ルール111を生成す る。構文解析ルール910の例を図14に示す。網掛けの部 分が埋め込まれたC言語の処理であり、ルールの右辺の 構成要素に対応するキーワード/テキストモデルの情報 を繋ぎ合わせ、ルールの左辺の構成要素に対応するキー ワード/テキストモデルの情報を生成する処理を行なう ものである。

【0035】図1において、yacc113は、生成された構文解析ルール111を入力として、構文解析ルール111に従った構文解析を行なう構文解析部105を生成する。DTD106から構文解析部105を生成する過程で人手を要するのは、論理構造定義を非構造化文書101の記述様式に合わせて変更し、差分DTDデータ109を生成する部分のみであり、残りの処理は自動的に行なわれる。

【0036】図1の構文解析部105は、キーワード/テキストモデル104に対して構文解析ルール111に従った構文解析を行なう。当該構文解析は、概して、次の2つのステップからなる。第一に、各テキストがどの論理構造要素に対応するのかを、隣接するキーワードに基づいて決定する。第二に、ツリー状表現のDTDにおけるより下位の論理構造要素群をより上位の論理構造要素にまとめあげる。すなわち、当該ツリーの葉に相当する各論理構造要素が満たされたことから、それに対応する根に相当する論理構造要素が満たされたこととし、この根を新たな葉とみなして上記動作を繰り返し、最終的に最上位の論理構造要素を満たすことができたならば、入力されたキーワード/テキストモデルを当該DTDから生成された構文解析ルール111に適合するモデルとして認識する。

【0037】本実施例においては、図8に示すキーワード/テキストモデルが入力され、例えば、「号番号」の"(1)"およびそれに続くテキスト"第1信号 警戒水位に達したことを知らせるもの"を読み取ると、まず、当該テキストが「号番号」なるキーワード"(1)"に隣接していることから、当該テキストは「号番号」に続く論理構造要素「号規定」に対応すると

決定する。同様の処理を当該キーワード/テキストモデ ル中のすべてのテキストについて行なう。次に、例え ば、上記の処理において"(1)" "第1信号 水位に達したことを知らせるもの"という並びを読み取 ったことにより、論理構造要素「号番号」および「号規 定」が満たされたので、これらに対応する上位の論理構 造要素「号」が満たされたと認識する。同様の処理によ り、隣接するすべての「号」、「号」の直前に位置する 「条番号」、およびそれに続くテキスト"水防法~とす る。"に対応する「初項規定」が満たされると、これら に対応する上位の論理構造要素「条」が満たされたと認 識する。このようにして最終的に最上位の論理構造要素 「条例」が満たされたならば、図8に示すキーワード/ テキストモデル104を、図10に示す修正DTD108に基づ き生成された構文解析ルールに適合するモデルとして認 識する。

【0038】構文解析の過程で、認識した論理構造要素に相当するキーワード及びテキストに対して、タグとー 40 対一で対応する「タグ情報」を付加する。具体的には、構文解析によって、各論理構造要素に対応するキーワード/テキストモデルにおける要素が、「m番目からn番目まで(m,nは整数でm<=n)」という形で得られるため、キーワード/テキストモデルのm番目の要素に、該当する論理構造がその要素から始まることを意味する「開始タグ情報」を付加し、n番目の要素に対しては同様に「終了タグ情報」を付加する。この処理を、解析されたすべての論理構造要素について行う。そして、タグ情報の付加されたキーワード/テキストモデルから、キーワード 50

及びテキストに相当する文字列の前後にSGMLのタグを付加した仮SGML文書114を出力する。仮SGML文書の例を図15に示す。

12

【0039】この例に示すように、タグ情報は「開始タグ情報」と「終了タグ情報」とから構成され、しかも「終了タグ情報」は「開始タグ情報」の近くにあるとは限らない。例えば、開始タグ情報「<条番号>」に対応する終了タグ情報「</条番号>」はすぐ2行下にあるが、開始タグ情報「</条>」に対応する終了タグ情報「</条>」は対応する終了タグ情報「</条>」は図示されている範囲を超えてさらに下方に存在する。このため、仮SGML文書114が生成された段階で文書の構造を人手で修正しようとすると、対応する開始タグ情報と終了タグ情報とを文書全体にわたって探さなければならないため、多大な労力を要することになる。本発明においては、必要な修正をDTDの段階で完了しているため、生成される仮SGML文書114は入力された非構造化文書101に即したものであり、上記のような修正は必要ない。

【0040】同一の領域から複数のキーワードが抽出さ れた場合には複数個のキーワード/テキストモデルが生 成されるが、その場合には上記の構文解析処理をすべて のキーワード/テキストモデルに対して行う。誤ったキ ーワードを含むものは、構文解析に失敗する。構文解析 に成功するキーワード/テキストモデルが複数個存在す る場合には、例えば「抽出されたキーワード数が多い」 ということを条件に、最適なキーワード/テキストモデ ルを選択し、それに対応した仮SGML文書を出力する。図 7において非構造化文書の同一文字列から「冒頭題名」 と「題名」の二つのキーワードが抽出された例を用いて 説明すると、「題名」の方を選択して生成されるキーワ ード/テキストモデルは、構文解析に失敗する。これ は、修正DTDの修正部分の一行目において、冒頭題名は 条例の先頭に出現しうるが、「題名」は条例の先頭には 出現できないことが規定されているためである。そのた め、「題名」に対応するキーワード/テキストモデルに 対応する仮SGML文書は出力されない。一方、「冒頭題 名」を選択して生成されるキーワード/テキストモデル は構文解析に成功するため、図15に示すように、それに 対応した仮SGML文書が出力される。

【0041】DTD差分データ109が存在する場合には、そのデータを基にSGML文書修正部115が仮SGML文書114を修正する。具体的な処理内容を、図16を用いて説明する。SGML文書修正部は、DTD差分データ109に記述された内容に対応する部分的なSGML文書である変更部インスタンス1602を作成する。このとき、論理構造の内容を表す文字列を意味する「#PCDATA」を対応する文字列に置換する必要があるが、その文字列を、仮SGML文書における変更部1603において同一名称の構成要素の内容を示す文字列によって置換する。例えば、変更部インスタンス1602において二つのタグく公布文>及びく/公布文>に挟まれた「#

13

PCDATA」は、仮SGML文書における変更部1603において同名のタグで挟まれた文字列である「△△県水防信号規則をここに公布する」に置換される。同様にして、二つのタグ〈公布年月日〉〈/公布年月日〉に挟まれた#PCDATAは文字列「昭和24年10月6日」に置換され、〈例規番号〉〈/例規番号〉に挟まれた#PCDATAは文字列「△△県規則第78号」に置換される。変更部インスタンス1602においてタグ〈職名〉〈/職名〉〈に挟まれる#PCDATAのように、仮SGML文書における変更部1603に該当する同一名称の構成要素が存在しない場合には、強制的に「[なし]」という文字列 10を挿入することにする。

【0042】以上の置換作業によって作成した変更部インスタンス1602を、図1の仮SGML文書114における変更部分、すなわち図15の例では二つのタグ〈CHANGE〉と〈/CHAN GE〉によって挟まれた部分と置換する。これにより、予め対象文書に対して設定されていたDTD106に即したSGML文書116として得る。SGML文書116の例を図17に示す。このSGML文書は個別論理構造を直接反映したものであるため、従来の方法のように文書インスタンスを個別論理構造へと変換する必要がない。

【0043】ところで、認識対象文書に出力書式定義が与えられ、それに従った出力が行なわれる場合がある。また、論理構造定義が予め用意されている場合には、それを出力する際の出力書式定義が同時に与えられていることが多い。そして、特に定型文書の電子化については、従来の記述様式との互換性を保つため、出力書式定義が認識対象文書の記述様式に沿った形で作成されていることが多い。

【0044】上記の実施例において、キーワード抽出ル ール103は人手によって作成したものであるが、認識対 象の文書に対して例えば図18に示すような出力書式定義 が与えられており、かつ出力書式定義が認識対象文書の 記述様式を基に作成されている場合や、出力書式定義に 従って出力されている場合には、これを参照してキーワ ード抽出ルールを生成することも可能である。例えば図 18は、論理構造要素「章番号」について「インデントは 1 cm」と規定されており、出力される文字列については 「"第", CONTENT, "章"」と定められている。また、文字 フォントには「Huge-font」が用いられる。この時、例 えばフォント「Huge-font」の文字ピッチが1cmである場 40 合には、行頭からスペース1文字分の位置から文字列 「第〇章」が記述されることが分かる。このように、出 力書式定義より、論理構造要素に対するキーワード抽出 ルールを作成することが可能であり、例えば図4に示し た形式で記述すると、「章番号 SPC1 "第" NUM1 "章"

【0045】認識対象文書の書式と出力書式定義に定義 された書式が完全に一致しない場合には、キーワード抽 出ルール103の人手による修正が必要になる。また、文

;」というルールを得ることができる。

字列情報が出力書式に記述されない場合には、人手によって文字列に関する書式条件を設定する必要がある。

14

【0046】キーワード抽出ルール103も構文解析ルール111と同様に、個々の文書に対して設定された情報を直接利用することによって、分野毎に共通した認識ルールを用いる従来方法では抽出できない個々の文書固有のキーワードが抽出可能となる。また、半自動生成を行うことにより、キーワード抽出ルール作成に要する労力を大幅に軽減することができる。

[0047]

【発明の効果】本発明によれば、論理構造認識に用いる構文解析ルール111を対象文書に設定された論理構造定義から直接的に生成することにより、ルールの作成に要する労力を軽減することができる。また、個々の文書の論理構造定義に記述されている論理構造に従った構文解析によって文書インスタンスを生成するため、構文解析の結果得られる文書インスタンスを共通論理構造に沿った形から個別論理構造に沿った形へと変換し直す必要がない。

20 【図面の簡単な説明】

【図1】本発明の実施例に係る構造化文書生成システムの動作概要を説明するブロック図である。

【図2】非構造化文書の例を示した図である。

【図3】図2に示した文書に対して設定されたSGML形式の 論理構造定義であるDTD(一部)を示した図である。

【図4】図3に示したDTDの一部をツリー状に表現した図である。

【図5】キーワード抽出ルールの例(一部)を示した図である。

) 【図6】図5に示したキーワード抽出ルールにおける書式 条件の記述要素を説明した図である。

【図7】キーワードの抽出例を示した図である。

【図8】キーワード/テキストモデルの例を示した図である。

【図9】構文解析ルール生成部の動作概要を説明するブロック図である。

【図10】修正DTDの例(一部)を示した図である。

【図11】DTD差分データの例を示した図である。

【図12】構文解析ルール生成部がDTDをyaccルールに変換する際に参照する変換規則を示した図である。

【図13】中間yaccルールの例(一部)を示した図である。

【図14】構文解析ルールの例(一部)を示した図である。

【図15】仮SGML文書の例(一部)を示したである。

【図16】SGML文書修正部の処理例を示した図である。

【図17】実施例に述べる方法によって最終的に得られる SGML文書の例(一部)を示した図である。

【図18】出力書式定義の例(一部)を示した図である。

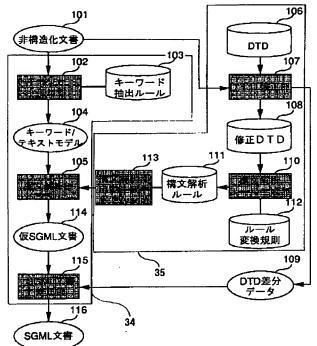
【図19】本実施例に係る構造化文書生成システムのハードウエア構成を示した図である。

【図1】

[図6]

図 1

⊠ 6



要素	意味
1	行頭.
\$	行末.
	文字列、ダブルクォーテーションで挟んで記述。
NUM{数字}	NUM1→整数、NUM2→カタカナ、NUM3→英小文字.
SPC{数字}	{数字}個分のスペース.
1	行頭からの任意個のスペース.
?	任意の一文字。
+	一文字以上の任意の文字列。
({要素}!(要素})	要案のOR.

【図7】

図7

公例公庭条号号号号条附布规布名录器套备器器即年器文 号号号号号号号号号号号号 △△県水助信号規則] [本本] [第1条] [(1) [(2) [(3) [(4) [| |附 l [別表] 別表番号

【図2】

図2

〇△△県水防信号規則

昭和24年10月6日 △△県規則第78号

【図11】

図11

防 信 ਲ

 <!DOCTYPE</td>
 CHANGE
 (公布,例規番号,題名) ->

 <!ELEMENT</td>
 CA布
 (公布文,公布年月日,公布者) ->

 <!ELEMENT</td>
 公布文
 (伊CDATA) ->

 <!ELEMENT</td>
 公布年月日(伊CDATA) ->
 ->

 <!ELEMENT</td>
 公布者
 (現名,氏名) ->

 ELEMENT 磁名
IELEMENT 氏名
IELEMENT 例規番号
IELEMENT 題名 (#PCDATA) (#PCDATA) (#PCDATA) (#PCDATA) --> -->

```
【図3】
```

®13.

【図13】

₩13

1301 → 条例: CHANGE opt0 本則 rep0;
1302 → opt0: |目次;
1303 → rep0: | rep0 附則;
CHANGE: opt1 opt2 目頭題名 公布 opt3;
opt2: | 圆頭節名;
opt2: | 圆頭節名;
ept = | 日頭章名:
目頭章名: | 日頭章名;
目頭章名: | 日頭章名;
目頭章名: | 日頭章名;
目頭章名: | 日頭章名;
日頭章名: | 日頭章名;
日頭章名: | 日頭章名;
日頭章名: | 母DOATA;
日頭節名: | 日頭節番号 | 日頭節題:
日頭節番号: | 母PCDATA;
日頭節翻: | 母PCDATA;

```
(公布, 例規番号, 題名, 本時, 時則*) -->
(公布文, 公布年月日, 公布者) -->
(学のATA) -->
(謝名, 氏名) -->
(学のATA) -->
(学のATA) -->
(学のATA) -->
(学のATA) -->
(学のATA) -->
(学のATA) -->
(学のATA)
             → <IDOCTYPE: 条例 [

→ <IELDENT 条例

→ <IELDENT 公布

→ <IELDENT 公布
302
303
304
             305
307
308
309
                                                                              (学にはは)
(学にはなり、)・(ではりましい項)・)
(学・)・(発見出し・発)・)(ではりましい項)・))・
(学者・)・(学見出し・発)・))・
(学のななな)
310
                                                                              (#PCDATA)
(節番号,節題,(数+I(条見出しI条)+))->
                                                                               (数番号,数題,(奈見出し1条)+)-
(#PCDATA)
                                                                              (#PCDATA)
(#PCDATA)
(見出し,条+)
(見出し,項+)
```

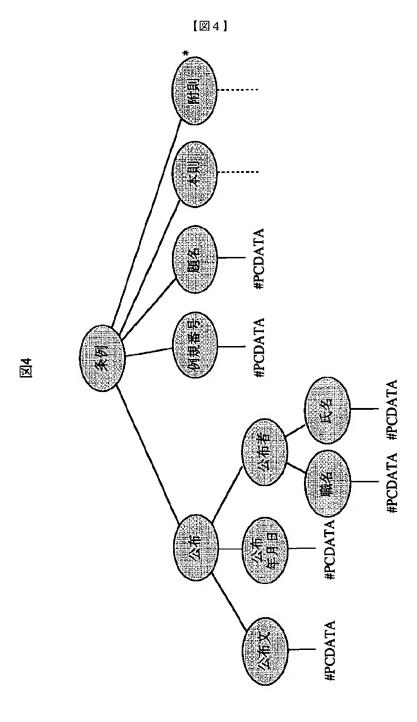
【図5】

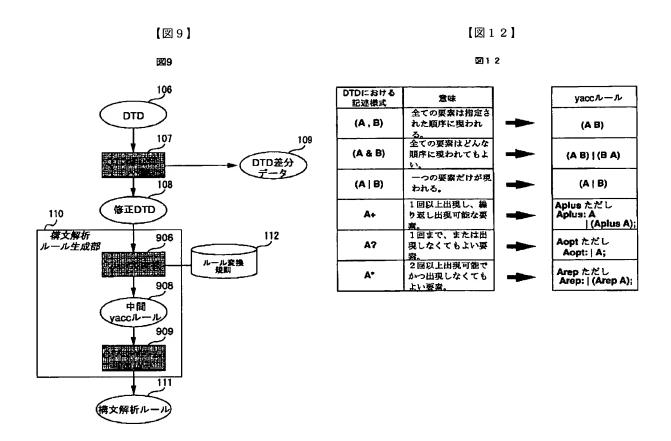
⊠ 5

[図8]

M8

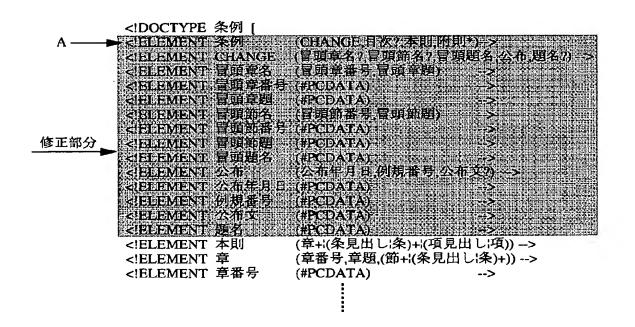
```
冒頭節番号:#PCDATA;
冒頭節題: #PCDATA;
冒頭題名: #PCDATA;
公布:公布年月日 例規番号 opt4;
opt4:(公布文;
公布文: #PCDATA;
公布年月日:#PCDATA;
例規番号: #PCDATA;
題名:#PCDATA;
图次: 目次本則 opt5;
opt5: 目表本則 opt5;
opt5: 目表本則 opt5;
opt5: 目表本則 opt5;
opD:: | 日次所則;
| 日次本則: plus0;
| 日次本: | plus0 | 日次章;
| 日次章: | 日次章番号 日次章題 op46 rep3;
| rep3: | rep3 | 日次節;
| op46: | 日次秦範囲;
| 日次章番号: #PCDATA;
| 日次章題: #PCDATA;
| 日次秦範囲: #PCDATA;
                                           【図18】
                                               図18
       (章番号(
                   (インデント;
                                                        1cm)
                   (フォント
                                                        Huge_font)
                   (出力文字列:
                                                         "第" CONTENT "章")
       (節番号(
                   (インデント:
(フォント :
                                                        1.5cm)
                                                       Large_font)
"第" CONTENT "節")
                   (出力文字列:
      ))
```





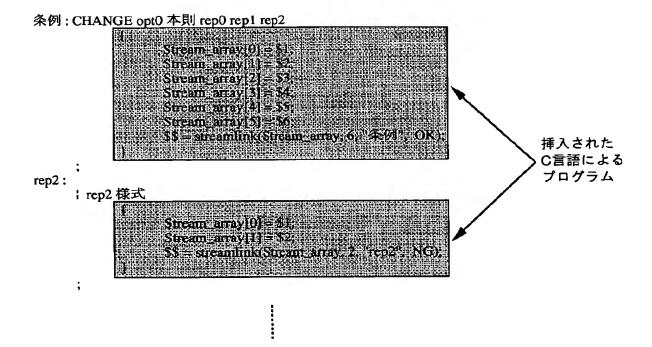
【図10】

図10

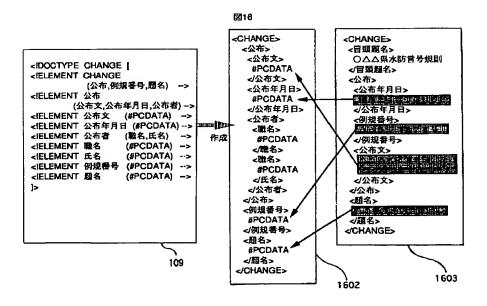


【図14】

図14



【図16】



【図15】

【図17】

⊠15

```
2017
<条例>
 <公布>
<公布文>
 ≪公布
△△県水防借号規則をここに公布する。
√公布
ぐ公布年月日>
 <公布者>
   <職名>
  (成名)
(成名)
(成名)
(成名)
  </公布者>
 〈公布〉

〈仍規番号〉
△△県規則第78号

〈例規番号〉
 <題名>
 △△県水助信号規則
 </組名>
 <本則>
<条>
<条番号>
   第1条

    (初項シ)
    (初項規定>
    水防法(昭和24年6月法律第193号)第13条第1項の規定による水防信号は、次に掲げるものとする。
    (初項規定>

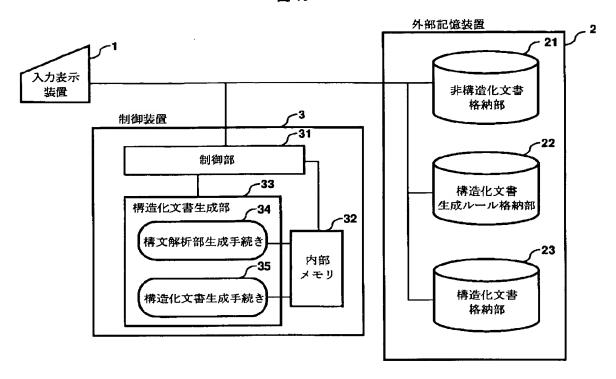
   <号>
<号番号>
    (1)
</号番号>
    <号規定>
    第1 信号 警戒水位に達したことを知らせるもの
</号規定>
```

<条例> <CHANGE> <冒頭題名> <日本組令>
○△△県木防信号規則
《/日頭題名>
《公布>
《公布年月日> 《公作年月日》 昭和24年10月6日 《/公布年月日》 《例規書号》 △△県規則第78号 《/例規書号》 √公布> <題名> △△県水助信号規則 </題名> </CHANGE> <本則> 〈条> <条番号> 第1条 </条番号> <初項> <の場合</p>
<初項規定>
本防法(昭和24年6月法律第193号)第13条第1項の規定による水防信号は、次に掲げるものとする。

< ⟨切明規定>
 ⟨号>
 (日)
 ⟨月番号>
 ⟨月提定>
 第1借身
 ★内規定>
 ★月規定> //号>

【図19】

図 19



1